(19)日本国特許庁 (JP)

# (12) 公開特許公報(A)

(11)特許出願公開番号 特開2001-7822

(P2001 - 7822A)

(43)公開日 平成13年1月12日(2001.1.12)

(51) Int.Cl.7

識別記号

FΙ

テーマコート\*(参考)

H04L 12/28 12/56 H04L 11/20

Н G

102C

審查請求 有 請求項の数17 OL (全 20 頁)

(21)出願番号

特顧2000-55103(P2000-55103)

(22)出願日

平成12年3月1日(2000.3.1)

(31)優先権主張番号 09/335908

(32)優先日

(32)優先日

平成11年6月18日(1999.6.18)

(33)優先権主張国

米国 (US)

(31)優先権主張番号 09/460649

平成11年12月14日(1999, 12, 14)

(33)優先権主張国

米国 (US)

(71)出願人 000004237

日本電気株式会社

東京都港区芝五丁目7番1号

(72) 発明者 ディアスー・ジー・キャペンディッシュ

アメリカ合衆国、ニュージャージー

08540 プリンストン, 4 インディペン デンス ウエイ、エヌ・イー・シー・ユ

ー・エス・エー・インク内

(74)代理人 100097157

弁理士 桂木 雄二

## (54) 【発明の名称】 データフロー制御スイッチ及びそのスケジューリング方法

### (57)【要約】

【課題】 実装及び制御が容易なパイプラインスケジュ ーラおよびクロスバ高速スイッチファブリックの入線間 での公平なスケジューリングが可能なパイプラインスケ ジューラを提供する。

【解決手段】 時間軸をフレーム化し、将来のタイムス ロットを予約するための優先マトリクスを用いたラウン ドロビン方式により、スケジュールモジュールが偶数個 か奇数個に関係なく、タイムスロットの規則的な巡回順 序が得られる。さらに、繰越しラウンドロビンパイプラ インスケジューラ (CORPS) は多数のポートへのス ケーラビリティを実現する。また、CORPSは、将来 のスロットのパケットをスケジューリングすることによ り、ラインごとスロットごとに1つのスケジューリング 決定を行う。スケジューリングされるキューの選択は任 意であるため、本発明は、トラフィックのサービス品質 をサポートすることに適している。CORPSは、出力 ボート間の競合を公平に解決する。

	1	
T17 T18 T19 T17 T18 T20 T20 T19	T14 T15	7-4F4
120 118 118	T12   T13   T	7
114 116 116	T10 T11 T	V-4F3
716 715 714	T 8 T 8T	-
	1	V-4F2
712 710 81	13	-
5555	Ę	-4F1
3M4 T8 T7 SM2 T7 T6 SM2 T6		76
బ్బే బ్	ı	

2

#### 【特許請求の範囲】

【請求項1】 ネットワークにおけるデータのフローを 制御するスイッチにおいて、

1

複数の入力ポートと、

複数の出力ポートと、

前記複数の出力ポートのうちの指定出力ポートへデータ を送るように、前記複数の入力ポートのうちの特定の入 力ポートをスケジューリングする複数の入力ポートスケ ジュールモジュールを有するスケジューラと、からな

現在のスケジュールモジュールは、

前のスケジュールモジュールからスケジューリングメッ セージを受信し、

前記現在のスケジュールモジュールが前記指定出力ポー トにアクセスしようとする将来のタイムスロットを計算

前記将来のタイムスロットが前記現在のスケジュールモ ジュールによって既に予約されているかどうか、前記将 来のタイムスロットが阻止されているかどうか、及び前 によって取られているかどうかに基づいて、前記将来の タイムスロットが有効かどうかを判断し、

有効な場合には、前記将来のタイムスロットを取り、前 記スケジューリングメッセージに前記将来のタイムスロ ットが取られたことを示す情報を入れる、

ことを特徴とするデータフロー制御スイッチ。

【請求項2】 前記スケジューラは、前記将来のタイム スロットが予約されている場合及び取られている場合の いずれかである時には、前記将来のタイムスロットを所 定数のタイムスロットだけ前進させることを特徴とする 30 ップ(d)に戻るステップと、 請求項1記載のデータフロー制御スイッチ。

【請求項3】 前記複数の出力ポートのそれぞれに対し て別々のキューを維持する仮想出力キューイング (VO Q)を用いて、前記複数の入力ポートを通じて入力され たデータをキューイングすることを特徴とする請求項1 記載のデータフロー制御スイッチ。

【請求項4】 あるボートに対する前記仮想出力キュー イングは、他のポートに対する前記仮想出力キューイン グとは独立であることを特徴とする請求項3記載のデー タフロー制御スイッチ。

【請求項5】 前記仮想出力キューイングのサービスレ ートは予測可能かつ調整可能であることを特徴とする請 求項3に記載のデータフロー制御スイッチ。

【請求項6】 前記スケジューラは、重み付きラウンド ロビンに基づいて、前記指定出力ポートを選択すること を特徴とする請求項1記載のデータフロー制御スイッ チ。

【請求項7】 複数の入力ポートスケジュールモジュー ルを有するスイッチの複数の入力ポートに到着する入力 信号を当該スイッチの複数の出力ポートに送るようにス 50 法。

ケジューリングする方法において、

- a) 現在のスケジュールモジュールが、前のスケジュー ルモジュールからスケジューリングメッセージを受信す るステップと、
- b) 前記現在のスケジュールモジュールが、前記複数の 出力ポートのうちの1つにアクセスしようとする将来の タイムスロットを計算するステップと、
- c) 前記複数の出力ポートのうちの1つを前記将来のタ イムスロットでの送信用にスケジューリングするように 10 選択するステップと、
  - d) 前記将来のタイムスロットが前記現在のスケジュー ルモジュールによって既に予約されているかどうかを判 断するステップと、
  - e) 前記将来のタイムスロットが前記現在のスケジュー ルモジュールによって予約されていない場合には、前記 将来のタイムスロットが阻止されているかどうかを判断 するステップと、
- f) 前記将来のタイムスロットが阻止されていない場合 には、前記将来のタイムスロットが他のスケジュールモ 記将来のタイムスロットが他のスケジュールモジュール 20 ジュールによって既に取られているかどうかを判断する ステップと
  - g) 前記将来のタイムスロットが、他のスケジュールモ ジュールによって既に取られている場合及び前記現在の スケジュールモジュールによって既に予約されている場 合のいずれかの場合には、前記スケジューリングメッセ ージから繰越し動作が既に開始されているかどうかを判 断するステップと、
  - h) 前記繰越し動作が既に開始されている場合には、前 記将来のタイムスロットを阻止状態に設定して前記ステ
  - i) 前記繰越し動作が開始されていない場合には、前記 将来のタイムスロットを所定数のタイムスロットだけ前 進させ、繰越しフラグをセットしてステップ(d)に戻 るステップと、
  - j) 前記将来のタイムスロットが他のスケジュールモジ ュールによって取られていない場合には、前記将来のタ イムスロットを取り、前記将来のタイムスロットが取ら れたことを示す情報を前記スケジューリングメッセージ に入れるステップと、
  - 40 k) 前記スケジューリングメッセージを次のスケジュー ルモジュールに渡すステップと、

からなることを特徴とするスケジューリング方法。

【請求項8】 前記複数の入力ポートを通じて入力した データは、各出力ポートに対して別々のキューを維持す る仮想出力キューイングを用いてキューイングされると とを特徴とする請求項7記載の方法。

【請求項9】 あるポートに対する前記仮想出力キュー イングは、他のボートに対する前記仮想出力キューイン グとは独立であることを特徴とする請求項8記載の方

【請求項10】 前記仮想出力キューイングのサービス レートは予測可能かつ調整可能であることを特徴とする 請求項8記載の方法。

【請求項11】 前記スケジューラは、重み付きラウン ドロビンに基づいて、前記指定出力ポートを選択すると とを特徴とする請求項7記載の方法。

【請求項12】 ネットワークにおけるデータのフロー を制御するスイッチにおいて、

複数の入力ポートと、

複数の出力ポートと、

前記複数の出力ポートのうちの指定出力ポートへデータ を送るように、前記複数の入力ポートのうちの特定の入 力ポートをスケジューリングするN個の複数の入力ポー トスケジューリングモジュールを有するスケジューラ と、

から構成され、

前記スケジューラは、

前記各入力ポートスケジューリングモジュールがリング

タイムスロット単位に、

各入力ポートスケジューリングモジュールが、前段のス ケジューリングモジュールから、ある予約タイムスロッ トの予約状況情報を受信し、

各入力ポートスケジューリングモジュールが、その予約 タイムスロットにおける当該入力ポートスケジューリン グモジュールからのパケット送出予約可否を決定し、 各入力ポートスケジューリングモジュールが、前段のス ケジューリングモジュールから受信した予約状況情報 に、自スケジューリングモジュールの予約結果を反映さ せて、次段のスケジューリングモジュールに送信する、 ことを特徴とするデータフロー制御スイッチ。

【請求項13】 複数の入力スケジューリングモジュー ルを有するパケットスイッチの入力ポートと出力ポート の接続状態を決定し接続を予約する(以下、スケジュー リングという。)方法において、

N個のタイムスロットを単位とするフレームを定義し て、前記フレーム時間内で、前記フレームの次フレーム 中のN個のタイムスロットでのスケジューリングを行

ことを特徴とするスケジューリング方法。

【請求項14】 前記スケジューリング方法は、

- a) 現在のスケジュールモジュールが、前のスケジュー ルモジュールからスケジューリングメッセージを受信す るステップと、
- b) 前記現在のスケジュールモジュールが、前記複数の 出力ポートのうちの1つにアクセスしようとする将来の タイムスロットを予め次フレーム内の特定のタイムスロ ットに決定するステップと、
- c) 前記複数の出力ポートのうちの1つを前記将来のタ イムスロットでの送信用にスケジューリングするように 50 (M. J. Karol, M. G. Hluchyj, S. P. Morgan, "Input

選択するステップと、

d) 前記将来のタイムスロットが他のスケジュールモジ ュールによって既に取られているかどうかを判断するス テップと、

4

- e) 前記将来のタイムスロットが他のスケジュールモジ \_ユールによって取られていない場合には、前記将来のタ イムスロットを取り、前記将来のタイムスロットが取ら れたことを示す情報を前記スケジューリングメッセージ に入れるステップと
- 10 f)前記スケジューリングメッセージを次のスケジュー ルモジュールに渡すステップと、

からなることを特徴とする請求項13記載のスケジュー リング方法。

【請求項15】 前記スケジューリング方法は、 タイムスロットでのスケジューリング決定過程(接続決 定過程)の観点から見た場合、前記複数の接続決定過程

フレームの先頭で同時に開始され、

フレーム内で同時にパイプライン処理により進行し、

20 フレームの末端で同時に完了する、ことを特徴とする請 求項13記載のスケジューリング方法。

【請求項16】 前記スケジューリング方法は、 前記入力ポートスケジューリングモジュールが、フレー ムの先頭で同時に開始する前記各接続決定過程におい て、次のフレーム内の各々異なる予約タイムスロットを 対象として処理を開始することを特徴とする請求項13 記載のスケジューリング方法。

【請求項17】 前記スケジューリング方法は、

ある与えられた将来のタイムスロットにおけるN個の入 30 カポートスケジューリングモジュールの規則的な巡回順 序を定義するN×Nマトリクスを参照することによっ て、現在のフレームにおける入力信号が次のフレームで どの出力ポートへ送出されるかを決定することを特徴と する請求項13記載のスケジューリング方法。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明は、ネットワークによ るデータのフローを制御するネットワークシステムおよ びスイッチに係り、特に、大容量スイッチを通じてのデ 40 ータフローを管理するスケジューラに関する。

[0002]

【従来の技術】入力キュースイッチアーキテクチャは、 常に高速交換システムの有力な選択肢であった。それは 主に、入力バッファのメモリアクセス速度が、全交換容 量とともにスケールするのではなく、単一の入線の速度 とともにスケールするからである。しかし、入力バッフ ァ型スイッチは、HOL (head-of-line)プロッキングの 問題があることが以前から知られており、これにより全 スループットは58.6%という理論限界に制限される

Versus Output Queuing on a Space-Division Packet S witch", IEEE Transactions on Communications, Vol.C OM-35, No.12, pp.1347-1356, Dec. 1987、参照)。 【0003】最近になって、入力スイッチのHOLブロ ッキングの問題を克服するために、仮想出力キューイン グ(VOQ:Virtual Output Queuing)という入力キュ ーイング方式が提案された (Y. Tamir and G. Frazier, "High Performance Multi-queue Buffers for VLSI Co mmunication Switches", Proceedings of 15th Ann.Sym p. on Comp. Arch., pp.343-354, June 1988、および、 T. Anderson, S. Owicki, J. Saxe, C. Thacker, "High Speed Switch Scheduling for Local Area Networks", ACM Transactions on Computer Systems, pp.319-352, Nov. 1993、参照)。その考え方は、スイッチの各出力 ポートごとに別々のキューを設け、空き出力ポート宛の パケットが、別のポートに対する競合により進めない先 頭パケットによってサービスをブロックされる可能性が なくなるようにするというものである。この場合、NX Nスイッチは入力ポートごとにN個のキュー、すなわ ち、N<sup>1</sup>個のキューを有する。他の研究者によって議論 されているように (A. Mekkittikul, N. McKeown, "A P ractical Scheduling Algorithm to Achieve 100% Thro ugh-put in Input-Queued Switches", Proceedings of Infocom98, April 1998、参照)、VOQ法をさらに研 究することによって、高性能のスケジューラの設計によ り実に100%のスループットが達成可能であることが 示されている。

5

【0004】従って、VOQ入力バッファ型スイッチの スケジューラは高速入力バッファ型スイッチの重要な設 計ポイントのうちの1つとなる。VOQの場合、スケジ 30 ューラは、通常の先入力先出力(FIFO)入力キュー イングアーキテクチャの場合よりも、バックログのある 入力ポートから出力ポートへパケットを交換するのには るかに多くの選択肢を有する。バックログのある入力ポ ートのうちで、あらゆる入出力ポート対を選択すること ができる。

【0005】とのようなスケジューラに対する研究のほ とんどは以下のように分類することができる。集中スケ ジューラは、スケジューラがN'個のすべてのVOQに 関する情報を有する単一のエンティティであって、バケ ットスロットごとにすべての可能な入出力ポート対に関 するスケジューリング決定を行うものである(例えば、 A. Mekkittikul, N. McKeown, "A Practical Schedulin g Algorithm to Achieve 100% Through-put in Input-Q ueued Switches", Proceedings of Infocom98, April 19 98、参照)。

【0006】他方、分散スケジューラは、スケジューラ がいくつかの機能ブロック(通常は入力あるいは出力ポ ート当たり1又は2個のブロック、あるいは、入出力ク

る(例えば、N. McKeown, M.Izzard, A. Mekkittikul, W. Ellersick, M. Horowitz, "The Tiny Tera: A Packe t Switch Core", IEEE Micro, Jan/Feb 1997, pp.26-3 2、および、Y. Tamirand H-C Chi, "Symmetric Crossba r Arbiters for VLSI Communication Switches", IEEE Transactions on Parallel and Distributed Systems, Vol.4, No.1,pp.13-27, 1993、参照)。

6

【0007】図1は、集中スケジューラの一例を示す概 略的ブロック図である。集中スケジューラは、スケジュ ーリング決定を行う前に、N'個の情報にアクセスする 必要がある。このようなスケジューラは、一般に、スケ ジューラを実装するハードウェアがスイッチラインの数 Nに強く依存するという意味で、スケーラブルではな

【0008】分散スケジューラは、ハードウェアに対し てスイッチポート数への依存性をより少なくする可能性 を有する。しかし、これまで提案されているものは依然 として、個々のパケットスロットに対するスケジューリ ング決定を行うことができる前に、N¹個のすべてのキ 20 ューに関する情報を提供する通信メカニズムを必要とす る。この通信は、並列に(SLIPスケジューラの場合 のように。N. McKeown, M. Izzard, A. Mekkittikul, W. Ellersick, M. Horowitz, "The Tiny Tera: A Packet Switch Core", IEEE Micro, Jan/Feb 1997, pp.26-3 2、参照)、あるいは、ラウンドロビン方式で(Y. Tami r and H-C Chi, "Symmetric Crossbar Arbiters for VL SI Communication Switches", IEEE Transactions on P arallel and Distributed Systems, Vol.4, No.1, pp.1 3-27, 1993、参照) 行うことが可能である。

【0009】図2(A)及び(B)は、並列方式及びラ ウンドロビン方式のアーキテクチャをそれぞれ示す模式 図である。図2(A)における並列通信アーキテクチャ では、各ブロックがスイッチのサイズに陽に依存してし まう。各ブロックがN'個のメッセージを受け取らなけ ればならないからである。<br />
図2 (B) におけるラウンド ロビンアーキテクチャはこの問題点を克服するが、別の 問題点を生じる。すなわち、すべての出力ポートに関す るスケジューリング決定を達成するためには、メッセー ジ受渡しは、単一のパケットスロット中に1ラウンドを 完了しなければならないという点である。これは、スケ ジューリング決定よりも少なくともN倍高速なメッセー ジ処理を必要とする。

【0010】さらに最近になって、ラウンドロビン・グ リーティ・スケジューラ(RRGS:Round-Robin Gree dy Scheduler)が提案された。これは、メッセージパッ シング(受渡し)に基づくスケジューラであり、各入力 ポートがスケジューリング決定を行い、この情報をラウ ンドロビン方式で次のボートに渡すものである(本出願 人による特願平11-172584号を参照)。メッセ ロスポイント当たり1ブロック) に分割されたものであ 50 ージ受渡し速度要求条件を緩和するために、RRGSは

パイプライン機能を導入している。入力ポートは、十分 将来のスロットに関するスケジューリング決定を行い、 メッセージ受渡しメカニズムがこの情報を他の入力ポー トに広めるのに十分な時間があるようにする。RRGS は高速なスケジューリングを実現することができる。 【0011】先ず、一般的なパイプライン型スケジュー ラのアーキテクチャについて説明する。図3は入力バッ ファスイッチアーキテクチャを例示する模式図である。 スイッチアーキテクチャに関して、スケジューリング 適用されると仮定する。また、仮想出力キュー(VO Q)を用いてHOLブロッキング問題に対処すると仮定 する。

【0012】さらに、固定サイズパケットおよび一様リ ンク速度を仮定する。時間はスロット化される。1つの スロットは、出力リンクによる1パケットの送信にかか る時間として定義される。出力ポート競合が存在しない 場合、ノンブロッキングクロスバは、タイムスロット当 たりNパケットまでを交換することができる。スケジュ ーラの基本的な仕事は、スロットととに、空でないN' 個のVOQキューのうちのいずれが出力ポートにアクセ スすることができるかを判断することである。効率のた めに、スケジューラは、1タイムスロット内でバックロ グのあるキューの間のすべての競合を解決しなければな

【0013】ライン速度が増大すると、スケジューリン グアルゴリズムが大容量スイッチにもスケーラブルであ ることが重要となる。従って、分散アーキテクチャが有 力であると思われる。分散アーキテクチャでは、高速ス イッチにおいてパケットスケジューリングに要求される 30 きつい処理時間が緩和されるからである。例えば、10 Gbit/sのライン速度の16×16ポートスイッチ で、スケジューリング決定は、各パケット送信時に行わ なければならず、424ビットのATMセルに対して4 2 n s である。シーケンシャルスケジューラを使用する 場合、各決定は、16×16スイッチでは0.16ns 未満で行わなければならない。N'個の決定をしなけれ ばならないからである。光コアを使用する場合、光コア の全交換帯域幅要求条件をそのままにして、電子ハード ウェアをポートごとに分散することには意味がある。さ 40 チャートである。図5では、4個のSM1~SM4と、 らに、分散スケジューラは、当然、任意のライン数にあ わせてスケールされる。図4にそのようなスケジューラ を例示する。

【0014】図4において、各クロスバ入力ポートは、 入力ポートスケジューラモジュール(SM:Scheduler Module) を有する。各SMは、個別のIDであるSM-IDを有する。ライン数とのスケーラビリティを維持す るために、SMは、隣の1個のSMとのみ通信すること が許される。これにより、SMハードウェアプロックは

とが保証される。SM通信チェインが図4に示されてい る。これは、タイムスロット、スロット所有権、および 出力ポート予約のようなスケジューリング情報を通信す るために使用される。クロスバモジュールとSMとの間 の唯一の相互作用は、グローバルクロックを通じてのも のである。これは、あらゆるSMに、どのスロットが現 在のシステムタイムスロット (CTS: Current system Time Slot) であるかということと、CTSで交換され る入出力ポート対に関する現在の決定テーブル(図示せ は、純粋なノンブロッキングN×Nクロスバスイッチに 10 ず)とを知らせる。これは、スケジューラによって書き 込まれ、クロスバファブリックによって読み出されるグ ローバルメモリによって実現することが可能である。

8

【0015】タイムスロットごとに、各SMは、アクセ ス要求先の出力ポートに関して完全な選択の自由がある と仮定される。同様の選択をするSMどうしは「コリジ ョン」(衝突)を生じ、これは、与えられたスロットに 対するグローバルスケジューリングパターンを決定する 前に解決する必要がある。SMが、他のすべての要求に 関する現在の情報を有することになる場合、通信チェイ 20 ンは、スケジューリング決定の速度よりもN倍速い速度 で動作しなければならない。すなわち、SMは、1つの スケジューリング決定を行う前に、N個のメッセージを 受信することができなければならない。

【0016】SMハードウェアの速度をライン速度とと もにスケーラブルに保つために、Nルックアヘッド(先 読み) スケジューリング方式を使用することが可能であ る。すなわち、各SMは、現在のスロットの少なくとも Nスロット先のタイムスロットに関してスケジューリン グ決定をすることになる。この機能により、SMは、ス ケジューリング決定をする前に、同じタイムスロットに 対してなされている他のスケジューリング決定に関して 知っていることが保証される。さらに、この機能は、通 信チェインを入力ライン速度のN倍に高速化する必要が ない。RRGSは上記のような、分散スケジューリン グ、パイプラインスケジューリングの特徴と、Nルック アヘッド(先読み)スケジューリングの特徴を備えてい る.

【0017】図5は、4×4クロスパースイッチを用い た場合のRRGSスケジューリングの一例を示すタイム それらの入力が出力ポートを選択するタイムスロットT 6、T7···との関係が示されている。

【0018】図5において、例えばタイムスロットT5 で、SM1はタイムスロットT10で送信を行うための 出力ポートの選択(スケジューリング)を行い、SM3 はタイムスロットT9におけるスケジューリングを行っ ている。また、次のタイムスロットT6では、SM1は タイムスロットT8におけるスケジューリングを行って いる。以下同様である。

任意のN×Nクロスバファブリックで使用可能であると 50 【0019】上記のように各SMがスケジューリングを

行い、その結果を次段のSMに転送することによって、あらゆるSMが、既にスケジューリングされたポートに関する情報を適時に得ることが保証される。あるSMが、前の「訪問者(visitor)」(即ち、1タイムスロット前のSM)によって既に選ばれた出力ポートを選ぶことを避ければ、コリジョンを完全に回避することができる。

#### [0020]

【発明が解決しようとする課題】しかしながら、RRGSでは、一つのSMが予約を行っていくタイムスロットの巡回順序が複雑になる。図6は、図5を個々のSMのタイムスロット巡回順序に着目して表現したタイムチャートである。例えば、SM1について見ると、タイムスロット巡回順序は、T10、T8、T11、T9・・・となり、時系列的あるいは逆時系列的な一定の規則的順序にはなっていない。これはRRGSの実装及び制御が複雑になるという問題を示している。

【0021】さらに、前記特願平11-172584号に示されるように、RRGSは、SMが偶数の場合と奇数の場合でスケジューリング動作が異なる。これは、S 20 Mを追加する際に制御を変更しなければならないことを示しており、実装及び制御が複雑になるという問題がある。

【0022】また、RRGSでは、SMが、まだ選ばれていない出力ボートを選ぶように制限されるため、VOQサービスレートは予測が困難になる。さらに、重大な公平性の問題が生じる。例えば、図4において、SM#1とSM#2は与えられた出力ボートのキューにコンスタントにバックログがあり、他のSMの対応するキューは空であるとする。この場合、SM#1は、図5にて定 30 義される巡回順序においてSM#2の前に4スロットのうちの3スロットを訪れるため、4スロットのうち3スロットはSM#1によって取られることになる(前記特願平11-172584号を参照)。

【0023】このように、上記のRRGSスケジューラは高速なスケジューリングを実現することが可能であるが、実装及び制御が複雑になるという問題がある。また、予測可能かつ調整可能なサービスレートを実現できない。また、上述したようにVOQのいくつかが他のVOQの状態によりスケジューリングを妨げられるという公平性の問題もある。

【0024】本発明の目的は、RRGSの実装及び制御の複雑さを解消した簡易なスケジューラの基本方式を提供することにある。

【0025】本発明の他の目的は、VOQキューがスケジューリングを行う際の完全な選択の自由を可能にする 大容量スイッチのためのスケジューラを提供することに ある。

【0026】本発明のさらに他の目的は、VOQサービ 用いて、前記入力ポートを通じてデータ入力をキューイスレートを予測可能かつ調整可能にするスケジューラを 50 ングする。あるいは、個々のポートに対する仮想出力キ

提供することにある。

【0027】本発明のその他の目的は、いずれのVOQも他のVOQの状態に拘わらず同じ確率でスケジューリングされるという意味で公平であるようなスケジューラを提供することにある。

10

【0028】スケジューラ設計におけるもう1つの制約は、次にスケジューリングされる与えられた入線に属するN個のVOQのうちのどのVOQを、スケジューラの制御から外すかの決定である。換言すれば、入力ボートでとに、どの出力ボートが次にスケジューリングされるかを、ある外部エンティティが全く自由に決定することである。この要請は将来のサービス品質(QoS)のサボートにとって重要である。これによりVOQの予測可能なサービスレートをより予測可能にする最大スループットを低下させる可能性があることは明らかである。しかしながら、これは重要な点である。スイッチ全体のスループットの最大化は、一部のキューの枯渇、ひいては、それらのキューに関連するフローも妨げられる可能性があるからである。

#### [0029]

【課題を解決するための手段】本発明の第1の観点によ れば、ネットワークにおけるデータのフローを制御する スイッチは、複数の入力ポートと、複数の出力ポート と、複数の入力ポートスケジュールモジュールを有する スケジューラとを有する。各スケジュールモジュール は、前記複数の出力ポートのうちの指定された出力ポー トヘデータを送るように、前記複数の入力ポートのうち の特定の入力ポートをスケジューリングする。スケジュ ールモジュールは、モジュール間でスケジューリングメ ッセージを受け渡し、各スケジュールモジュールは、当 **該スケジュールモジュールが指定出力ポートにアクセス** しようとする将来のタイムスロットを計算する。スケジ ュールモジュールは、更に、前記将来のタイムスロット が当該スケジュールモジュールによって現在予約されて いるかどうか、前記将来のタイムスロットが阻止されて いるかどうか、及び前記将来のタイムスロットが他のス ケジュールモジュールによって取られているかどうかに 基づいて、前記将来のタイムスロットが有効かどうかを 判断する。有効な場合、スケジュールモジュールは前記 将来のタイムスロットを取り、スケジューリングメッセ ージに前記将来のタイムスロットが取られたことを示す 情報を入れる。

【0030】スイッチのスケジューラは、前記将来のタイムスロットが予約されているとき又は取られているときに、前記将来のタイムスロットを所定数のタイムスロットだけ前進させる。

【0031】スイッチは、前記出力ポートのそれぞれに対して別々のキューを維持する仮想出力キューイングを用いて、前記入力ポートを通じてデータ入力をキューイングする。 あるいは 個々のポートに対する仮想出力キ

ューイングは、他のポートに対する仮想出力キューイン グとは独立であることも可能である。さらに、スイッチ は予測可能かつ調整可能な仮想出力キューイングのサー ピスレートを有する。また、スイッチスケジューラは重 み付きラウンドロビンに基づいて指定出力ポートを選択 する。

【0032】本発明の第2の観点によれば、スイッチの 複数の入力ポートに到着する入力パケットをスイッチの 複数の出力ポートに送るようにスケジューリングする方 法が提供される。ととで、スケジューラは、複数の入力 10 ポートスケジュールモジュールを有する。この方法は、

- a) 現スケジュールモジュールが、前のスケジュールモ ジュールからスケジューリングメッセージを受信するス テップと
- b) 前記現スケジュールモジュールが、前記複数の出力 ポートのうちの1つにアクセスしようとする将来のタイ ムスロットを計算するステップと、
- c) 前記将来のタイムスロットにおける送信用にスケジ ューリングするように前記複数の出力ポートのうちの1 つを選択するステップと、
- d) 前記将来のタイムスロットが前記現スケジュールモ ジュールによって既に予約されているかどうかを判断す るステップと.
- e) 前記将来のタイムスロットが前記現スケジュールモ ジュールによって予約されていない場合、前記将来のタ イムスロットが阻止されているかどうかを判断するステ ップと
- f) 前記将来のタイムスロットが阻止されていない場 合、前記将来のタイムスロットが他のスケジュールモジ テップと、
- g) 前記将来のタイムスロットが、他のスケジュールモ ジュールによって既に取られているか又は前記現スケジ ュールモジュールによって既に予約されている場合、前 記スケジューリングメッセージから、繰越し動作が既に 開始されているかどうかを判断するステップと、
- h) 前記繰越し動作が既に開始されている場合、前記将 来のタイムスロットを阻止状態に設定してステップdに 戻るステップと、
- のタイムスロットを所定数のタイムスロットだけ前進さ せ、繰越しフラグをセットして、ステップdに戻るステ
- j) 前記将来のタイムスロットが他のスケジュールモジ ュールによって取られていない場合には前記将来のタイ ムスロットを取り、前記将来のタイムスロットが取られ たことを示す情報を前記スケジューリングメッセージに 入れるステップと、
- k) 前記スケジューリングメッセージを次のスケジュー ルモジュールに渡すステップと、からなる。

12

【0033】複数の入力ポートを通じて入力するデータ は、各出力ポートに対して別々のキューを維持する仮想 出力キューイングを用いてキューイングされる。個々の ポートに対する仮想出力キューイングは他のポートに対 する前記仮想出力キューイングとは独立である。また、 前記仮想出力キューイングのサービスレートは予測可能 かつ調整可能である。スケジューラは、重み付きラウン ドロビンに基づいて、前記指定出力ポートを選択する。 【0034】本発明の第3の観点によれば、ネットワー クにおけるデータのフローを制御するスイッチは、複数 の入力ボートと、複数の出力ボートと、前記複数の出力 ポートのうちの指定出力ポートへデータを送るように、 前記複数の入力ポートのうちの特定の入力ポートをスケ ジューリングするN個の複数の入力ポートスケジューリ ングモジュールを有するスケジューラと、から構成さ れ、前記スケジューラは、前記各入力ポートスケジュー リングモジュールがリング状に接続され、タイムスロッ ト単位に、各入力ポートスケジューリングモジュール が、前段のスケジューリングモジュールから、ある予約 20 タイムスロットの予約状況情報を受信し、各入力ポート スケジューリングモジュールが、その予約タイムスロッ トにおける当該入力ポートスケジューリングモジュール からのパケット送出予約可否を決定し、各入力ポートス ケジューリングモジュールが、前段のスケジューリング モジュールから受信した予約状況情報に、自スケジュー リングモジュールの予約結果を反映させて、次段のスケ ジューリングモジュールに送信する。

【0035】複数の入力スケジューリングモジュールを 有するパケットスイッチの入力ポートと出力ポートの接 ュールによって既に取られているかどうかを判断するス 30 続状態を決定し接続を予約する(以下、スケジューリン グという。) 方法は、N個のタイムスロットを単位とす るフレームを定義して、前記フレーム時間内で、前記フ レームの次フレーム中のN個のタイムスロットでのスケ ジューリングを行うことを特徴とする。

- 【0036】上記スケジューリング方法は、
- a) 現在のスケジュールモジュールが、前のスケジュー ルモジュールからスケジューリングメッセージを受信す るステップと、
- b) 前記現在のスケジュールモジュールが、前記複数の i) 前記繰越し動作が開始されていない場合、前記将来 40 出力ポートのうちの1つにアクセスしようとする将来の タイムスロットを予め次フレーム内の特定のタイムスロ ットに決定するステップと、
  - c) 前記複数の出力ポートのうちの1つを前記将来のタ イムスロットでの送信用にスケジューリングするように 選択するステップと、
  - d) 前記将来のタイムスロットが他のスケジュールモジ ュールによって既に取られているかどうかを判断するス テップト
  - e) 前記将来のタイムスロットが他のスケジュールモジ 50 ュールによって取られていない場合には、前記将来のタ

イムスロットを取り、前記将来のタイムスロットが取られたことを示す情報を前記スケジューリングメッセージ に入れるステップと、

f) 前記スケジューリングメッセージを次のスケジュー ルモジュールに渡すステップと、からなる。

【0037】さらに、上記スケジューリング方法は、タイムスロットでのスケジューリング決定過程(接続決定過程)の観点から見た場合、前記複数の接続決定過程が、フレームの先頭で同時に開始され、フレーム内で同時にパイプライン処理により進行し、フレームの末端で 10 同時に完了する。

【0038】また、このスケジューリング方法は、前記入力ポートスケジューリングモジュールが、フレームの 先頭で同時に開始する前記各接続決定過程において、次 のフレーム内の各々異なる予約タイムスロットを対象と して処理を開始する。

【0039】上記スケジューリング方法は、ある与えられた将来のタイムスロットにおけるN個の入力ボートスケジューリングモジュールの規則的な巡回順序を定義するN×Nマトリクスを参照することによって、現在のフ 20レームにおける入力信号が次のフレームでどの出力ボートへ送出されるかを決定する。

#### [0040]

【発明の実施の形態】本発明によるキャリーオーバ(繰越し)ラウンドロビン・パイプライン・スケジューラ

(Carry Over Round-robin Pipelined Scheduler、以下CORPSという。)は、高速クロスパファブリックに対する公平なスケジューラであり、従来技術のスケジューラの問題点を解決するものである。CORPSは、高速スイッチファブリックのライン速度およびライン数の双方に関するスケーラビリティ性を有する。ライン数に関するスケーラビリティのために、メッセージ受渡しを有する分散アーキテクチャが選択される。更に、RRGSと同様に、メッセージ処理要求条件をライン速度とともにスケーラブルに維持するために、パイプラインアーキテクチャが用いられる。

【0041】さらに、本発明によれば、時間軸を単にN個の連続するスロット列であるスロットフレームに分割して、時間をフレームの列とみなす。競合するスケジューラモジュールSM間のコリジョンを解決する基準を設 40定するために、優先マトリクスを使用する。N×N優先マトリクスは、将来の与えられたタイムスロットをSMが巡回する順序を定義するマトリクスである。マトリクスの行は現在のフレーム(現在のシステムスロットを含むフレーム)内のスロットをインデクス付けし、マトリクスの列は次に訪れるフレーム内のスロットをインデクス付けしている。マトリクスの要素は、どのSMが、列インデクスによって示される次フレーム内のスロットを「訪れる(visit)」べきかを指定する。

【0042】図7は4×4優先マトリクスを示す図であ 50 びメッセージ受渡し方式を維持しつつ公平性を提供する

14

り、図8は、図7に示したマトリクスに対するパイプライン化されたタイムスロット巡回順序を例示している。パイプライン化された決定プロセスは、優先マトリクスの使用に既に含まれていることに注意すべきである。例えば、システムの現在のタイムスロットが現フレームの第2スロットであるとき、SM#1が次フレームの第4スロットに関するスケジューリング決定をしている間に、SM#3は次フレームの第2スロットに関するスケジューリング決定をしている。

【0043】優先マトリクスを使用することにより時間 軸がフレーム化され、タイムスロット巡回順序が規則的 になる。例えば、フレームF1における各SMの動作に 着目すると、各SMのスケジューリング決定過程は、フ レームF1の先頭で同時に開始され、スケジューリング 決定を行うタイムスロットの巡回順序はT8→T7→T 6→T5→T8となり、フレームF1の末端で同時に完 了する。これは、図6に示したRRGSにおけるタイム スロット巡回順序(T10、T8、T11、T9・・

・)と比較して規則的になっている。このためSMの実装及び制御が容易になる。更に、N×N優先マトリクスはSMの個数に関して偶奇の区別なく、同一規則にてタイムスロットの巡回順序を定義する。

【0044】図9は5×5優先マトリクスを示す図であり、図10は、図9に示したマトリクスに対するパイプライン化されたタイムスロット巡回順序を例示している。フレームサイズは5タイムスロットとなるが、N=4の場合と同様に、タイムスロット巡回順序は規則的なものとなる。図8と同様に、フレームF1における各SMの助作に着目すると、各SMのスケジューリング決定過程は、フレームF1の先頭で同時に開始され、スケジューリング決定を行うタイムスロットの巡回順序がT10→T9→T8→T7→T6→T10となり、フレームF1の末端で同時に完了する。SMの個数に関して偶奇の区別なく同一規則にてN×N優先マトリクスを規定できるため、RRGSと比較してSMの実装及び制御が容易になる。

【0045】N×N優先マトリクスは、通信チェインメッセージ受渡しの同じ方向に、SMの列を回転させることによって生成される。これにより、あらゆるSMが、既にスケジューリングされたポートに関する情報を適時に得ることが保証される。あるSMが、前の「訪問者(visitor)」(即ち、1タイムスロット前のSM)によって既に選ばれた出力ポートを選ぶことを避ければ、コリジョンを完全に回避することができる。

【0046】以上のように、時間軸をフレーム化して優先マトリクスを用いた予約を行うことにより、SMの個数に関して偶奇の区別なくタイムスロット巡回順序が規則的なものとなり、SMの実装及び制御が容易になる。 【0047】更に、本発明では、分散アーキアチチャス ために、繰越し(キャリーオーバ)動作を導入する。この考え方は、あるスケジューラモジュールSMaが、それに先行するスケジューラモジュールSMによって所望の出力ボートが既に予約されているスロットを訪れるときに、処理しようとしたスロットから将来にNスロット分だけそのボートのスケジューリング試行を繰り越すというものである。もし当該スロットが同じ出力ボートに取られていることが分かれば、SMは所望の出力ボートがまだ取られていないスロットを見つけるまで更にNスロット先に進む。

15

【0048】図11は、複数のスケジューラモジュール SMの間での繰越し動作を例示する説明図である。繰越し動作は、与えられたタイムスロットにおいて「衝突している」SMの個数に依存してNフレームまで広げることができる。繰越し動作によって影響されるスロットは、コリジョン(衝突)を解決するために取られるスロットの集合(以下、コリジョン解決セットという。)とみなすことができる。なお、繰越し動作を受けたスロットは、後続するフレームですべてのSMにより再び訪問されるであろう。従って、繰越し動作によって取られるスロットは、潜在的に新たなコリジョンを受け、コリジョン解決セットの重量を引き起こす可能性がある。これは、複数のコリジョンを解決するためにN<sup>1</sup>個のフレーム、すなわち全部でN<sup>3</sup>個のスロットを必要とする可能性がある。

【0049】システムのメモリ要求条件を緩和すると共にスケジューリング遅延を短縮するために、繰越し動作によって影響されるフレームの個数は、繰越し動作を実行したSMが、当該コリジョンを解決するために取られた複数のスロットにわたって同じ出力ポートに対して他のスケジューリングをしないように制限される。換言すれば、1つのスロットが、同時に複数のコリジョンを解決するようには使用されない。

【0050】例えば、SMaが、与えられたポートpによって取られたスロットmを見つけ、これにより繰越し動作がトリガされると仮定する。この繰越し動作の結果としてSMaによって予約されたスロットをmxとする。スロット $mn(1 \le n < x)$ のいずれも、同じポートpについてはSMaにとって利用不可(阻止、ブロッキング)となる。従って、この阻止機能は、与えられた 40スロットに関する複数のコリジョンが禁止されることを保証する。

【0051】CORPSスケジューリングアルゴリズム について以下で説明する。先ず、通信チェインで渡されるメッセージと、スケジューリング決定が記録されるS Mデータベースについて説明し、その後、アルゴリズム の流れについて説明する。

【0052】各セルスロットで、チェイン内のあるSM リアレイは から次のSMに渡されるスケジューリング決定要素のべ 【0058】 クトルを定義する。Sメッセージは、たかだか最後のN 50 定義される。

個のセルスロットでなされたスケジューリング決定のスケジューリング要素(scheduling element、以下SEと記す。)を含む。すなわち、Sメッセージは、たかだかN個のSEを有する。Sメッセージは以下のフォーマットを有する。

16

【0053】図12は、Sメッセージのフォーマットを示す図である。同図において、Sメッセージの各スケジューリング要素SEは、存続時間(TTL: Time To Live)、タイムスロット ID (TSI: Time Slot ID)、S 10 M-ID、及び出力ポート ID (OPI: Output Port ID) からなる。

・存続時間(TTL)は、当該SEを生成したSMによって最初にNにセットされる。

・タイムスロットID(TSI)は、現在のTS(タイムスロット)からスロットがスケジューリングされるまでのスロット数として定義される、スケジューリングされるスロットのIDである。

・SM-1Dは、スケジューリング予約をした入力ポートスケジューリングモジュールのIDである。

0 ・出力ポートID(OPI)は、スケジューリングされる出力ポートのIDである。

【0054】スロットの最初に、各SMは先行するSMからSメッセージを受信する。これは、最後のN個のスロットに付けられたSEを含む。あらゆるSMは、タイムスロット当たりたかだか1回のスケジューリング決定を行う。SMPがスケジューリング決定を行う場合、SMPは以下の内容を有する新しいSEを作成する。

 $[0055] \cdot TTL = N$ 

・TSI=現在のスロットから選択されたタイムスロットまでの(それを含む)スロットの個数m

 $\cdot$  SM-ID=p

・OPI=タイムスロット(CTS+m) におけるバケットが入力ポート p から出力ポート q に交換されるような所望の出力ポート q。

【0056】スケジューリング決定にかかわらず、各S Mは、次のSMにメッセージを渡す前に、Sメッセージ 内の他のすべてのSEのTTLをデクリメントし、TT L=0のSEを廃棄する。

【0057】各SMは、(N+1)N個の位置を含むメモリアレイSCを有する。最初のN個の位置は、クロスパスイッチモジュールによって読み出される現フレームのスケジューリング決定を記録する。これらの位置は、すべてのSMの間で、現フレームに関する同一の情報を有し、いくつかの方法でクロスパコントローラによってアクセスされ得る。厳密にいえば、SMは、この情報を保持する必要はない。残りのN'個の位置は、将来のスケジューリング決定を記録するために使用される。メモリアレイは以下のフォーマットを有する。

【0058】図13に示すように、以下のフィールドが 定義される。

・タイムスロット I D: S C アレイへのインデクスである。 これは、S C 位置がスケジューリング情報を保持するタイムスロット I Dを与える。 これは、 クロスバモジュールによって提供されるグローバルクロックと同期する。 このフィールドは、 グローバルクロックが進行すると共にラップアラウンドする。

17

【0059】・阻止(Blockage): これはSMがスケジューリング予約をすることを阻止されている出力ボートの集合を定義する。このフィールドにはN個までのエントリが存在しうる。なお、最初は空である。

【0060】・予約(Reservations):これは与えられたタイムスロットに対するスケジューリング予約を記録する。CORPSは、現タイムスロット(CTS)に対してこのフィールド内のすべてのエントリがすべてのSMにわたり同一であることを保証する。従って、クロスバモジュールは、任意のSM(CTS)から、セルの現在の入出力スケジューリングを読み出すことができる。アルゴリズムの一貫性チェックは、クロスバコントローラが十分な処理時間を有する場合に、すべてのSMの間でこのフィールドを比較することにより、クロスバモジ20ュールによって実行されることができる。

【0061】 CORPSスケジューリングアルゴリズム 各SMは、ここで説明するCORPSスケジューリング アルゴリズムに従う。CORPSには、与えられたSM がどの出力ポートをスケジューリングしようとするかに 関する制約はない。どの出力ポートをスケジューリング しようとするかの選択は、各SMにまかされ、そのVO Qにサービスする固有のポリシーに従う。図14はCO RPSスケジューリングアルゴリズムを示すフローチャ ートである。以下、タスクボックス101~110につ 30 いて、同図のフローに従いながら説明する。

【0062】先ず、タスク101において、前のSMからSメッセージを受信し、各SEに対してTTL(存続時間)をデクリメントする。更に、与えられたSEに対してTTL>0の場合には、TSI(タイムスロットID)をデクリメントし、TSIにおけるメモリアレイSCを更新する。TTL=0の場合には、そのSEをSメッセージから除去する。また、キャリー(CARRY)フラグをCARRY=FALSEにリセットする(タスク109参照)。

【0063】続いて、タスク102(試行スロットの計算)において、適当な優先マトリクスを用いて、どの将来のタイムスロット(FTS: Future Time Slot)をスケジューリングしようとするかを計算する。簡単のため、そのマトリクスは、FTS=f(CTS.SM\_ID)の形の関数fにエンコードされうる。

【0064】更に、SMが送信用にどの出力ポート(OPIS)をスケジューリングしようとするかを選択する(タスク103:出力ポートの選択)。なお、出力ポートを選択するストラテジは、前のタスクの結果に依存す

る可能性がある。CORPSはこのストラテジを指定しない (例えば、出力ポートの重み付きラウンドロビン選択が使用可能である)。

【0065】続いて、SC(FTS)の予約エントリのうちで、SM-IDがこのスケジューリングを実行する SMに等しいものがあるかどうかを単にチェックする (タスク104:スロットを自分が所有しているかのテスト)。

【0066】もし、SM-IDがこのスケジューリングを実行するSMと異なるならば(タスク104のNO)、更に、SC(FTS)の阻止エントリのうちで、OPI(出力ポートID)が、スケジューリングを試みている出力ポートOPISに等しいものがあるかどうかをチェックする(タスク105:自分は阻止されているかのテスト)。

【0067】自分が阻止されているならば(タスク105のYES)、Sメッセージを次のSMに渡す(タスク106)。

【0068】自分が阻止されていないならば(タスク105のNO)、SC(FTS)の予約エントリのうちで、OP1(出力ポートID)が、スケジューリングを試みている出力ポートOPISに等しいものがあるかどうかをチェックする(タスク107:そのスロットは取られているかのテスト)。

【0069】そのスロットが取られていない場合には(タスク1070NO)、SC (FTS) に、自己のSM-IDを有しOPIがOPISに等しい予約エントリを作成し、TTL=N、TSI=FTSで、SM-IDは自己のIDに等しく、OPI=OPISであるSEを作成する(タスク108:スロットを取る)。その後、タスク106(Sメッセージの受け渡し)へ進む。

【0070】とのスロットを自分が所有している場合 (タスク104のYES) あるいはそのスロットが既に 取られている場合 (タスク107のYES) には、繰越し助作が既に開始されているかどうかを検査し、フラグ CARRY=TRUE/FALSEをチェックする。CARRY=TRUEの場合には、SC(FTS)の阻止フィールドに、OPI=OPISのエントリを作成し、そうでない場合にはCARRY=TRUEにセットし、40更に、FTS=FTS+Nにセットする(タスク109:繰越し)。

【0071】タスク109により繰越し動作が実行されると、続いて健全性チェックが行われる(タスク110)。即ち、FTSは、CTSから $2N^2$ より遠くに離れてはならない。(FTS-CTS)> $2N^2$ である場合(タスク1100NOK)、エラーメッセージを出して処理を中止する。FTS-CTS) $\le 2N^2$ の場合には(タスク11000OK)、タスク104へ戻る。

(タスク103:出力ポートの選択)。なお、出力ポー 【0072】CORPSアルゴリズムを用いることで以 トを選択するストラテジは、前のタスクの結果に依存す 50 下の利点が生じる。バックログのあるVOQは、最終的 にはそのSMによって選択されると仮定しても、枯渇することはない。VOQqがSMpによって選択されると仮定すると、図14によれば、SMpがqをスケジューリングすることに成功せずに予約ループを抜ける唯一の場合は、試みたスロットに対して阻止されている場合である。SMpが阻止されているとは、キューqが既にスケジューリングされているととを意味するが、以下の点に注意すべきである。ループを抜ける他の唯一の場合があるとすれば、健全性チェックを通る場合であるが、これは、繰越し動作が次のNフレームに空きスロットを見つけなかったことを意味する。1つのコリジョンにかかわるSMはたかだかN個であり、複数のコリジョンは阻止手続きによって禁止されるため、ループからこのようにして抜けることはない。

19

 $|n_i^{\alpha}(\Delta t) - n_i^{\alpha}(\Delta t)| \leq N$ 

である場合、m-フェア(m-公平)であるという。換言すれば、SMは、他のいずれのSMよりも前にN個の予約をすることはできない。

【0074】CORPSは、m-公平(1<m≦N)で ある。与えられたスロットtsにおいて出力ポートaに 対してm個のSMが衝突していると仮定する。衝突して いるm個のSMはそれぞれ、そのスロットに対して阻止 されてはいない。もし阻止されていれば、そのスロット が既に取られているかどうかのテストをすることさえで 30 きないからである(図14のタスク105)。 これらの m個のSMがスロットts において阻止されていない場 合、ts+nN(l<n≤i)の間にm個の空きスロッ トがなければならない。なぜならば、将来にこれらのス ロットにアクセスする唯一の方法は繰越し動作を通して であり、しかも、これらのSMはこれらのスロットに対 して繰越し動作を実行していないことが分かっている (さもなければそれらは t s において阻止されている) からである。このことは、次のiフレーム以内に、衝突 中のSMがそれぞれ q に対してスケジューリング要求を 40 することになることを意味する。ここで、それらは現フ レームのN個の連続するスロットに対して衝突し続け、 しかも、各コリジョン(衝突)はSMCとに次のiフレ ームに1つのスケジューリングを生成するとすれば、各 SMは、出力ポートqに対して次のiフレームに全部で Nスロット予約することになる。このように、コリジョ ンが解決されるiフレームのiN個のスロットから取ら れるスロットのいずれのサブセットも、他のSMよりも Nスロットより多い利益を有するSMを含むことはでき ない。

【0075】最後の注意は興味深いものである。それは、たとえ測定期間がどれほど長くても、連続してバックログのあるVOQは、他のSMの対応するVOQの前にN個より多くのパケットをサービスされることはないことを意味するからである。実際、十分長い期間では、すべての衝突するSMは厳密に同数の予約を得ることになる。

【0076】さらに、重い負荷のもとでは、共通の出力ポートを有するキューはすべて、それらのSMによって同じ回数だけ選択されると仮定すれば、すべて同じスループットを有する(図14のタスク108)。

【0077】CORPSアーキテクチャについていくつ かのコメントをしておかなければならない。SMどうし の間でスケジューリング情報を渡すために用いられる通 信チェインは、将来の少なくともN個のスロットである 限り、任意の方法でスロットのスケジューリングパター ンを変更するために使用することが可能である。例え ば、出力ポート予約を取り下げることも可能である。こ の機能は、SMがコリジョンにより遠い将来に予約をし 20 たばかりであるが、ちょうど次のスロットにおいて、要 求するポートが空いたことに気がついた場合に有用とな る。SMが、同じパケットに対して別の予約(より近い もの)をする場合、遠いほうの予約は、取下げがなけれ ば帯域の浪費を引き起こす。しかし、予約取下げは、上 記の性質に悪影響を及ぼす可能性もある。例えば、衝突 したSMが後で予約を取り下げた場合、同じコリジョン においてその後にスケジューリングされたパケットの遅 延に悪影響を及ぼす。換言すれば、i-1個の他のSM と衝突したSMが、この衝突による予約を後で取り下げ た場合、システムは、最初にi-1個のSMのみが衝突 したのと同じ状態にはない。このスケジューラは、最初 の設計目標を満たしながら、できる限り単純なものであ る。これにより、最終的な実装に要求されるハードウェ アは単純なままであることが保証される。

【0078】CORPSは、複数のフレームにわたりパケットスケジューリングを広げることによって衝突を解決する。従って、他のスケジューラに比べて、平均パケット遅延が大きくなると期待することはもっともである。このため、一様トラフィックのもとでCORPSのパフォーマンスを分析する。最終目標は、繰越し動作がどのくらいパケット遅延に影響するかを評価し、競合するスケジューリングアルゴリズムと比べて、システムから最大利用率を得ることである。

【0079】トラフィック負荷に対するパケット遅延に関してスケジューラのパフォーマンスを評価するために、CORPSの分析モデルを作成する。以下では、簡単のため、次の2つの主要な仮定をする。

【0080】(i) 一様トラフィック到着過程、および (ii) 各SMによるランダムなVOQキュー選択(図 50 14のタスク103)。 21

【0081】与えられたSMmの、出力ポートn宛のタ ーゲットVOQキューQaaを定義する。パケットは、強 度pでベルヌーイ過程に従ってあらゆる入力ポートに到 着する。具体的には、与えられたスロットにおいて、1 つのパケットがlつの入力ポートに到着する確率がpで ある。さらに、あらゆるバケットは、いずれの出力ポー ト宛の確率も等しい(仮定i)。従って、ターゲットV OQキューにおけるパケット到着過程は、パラメータp /Nのベルヌーイ分布を有する。

【0082】VOQ選択に関して、与えられたSMの空 でない各キューは、スケジューリングのために等確率で 選択される(仮定ii)。従って、任意のVOQに対し て、当該VOQが空でなければ、qは選択される確率で ある。以下、Chipalkatti等( "Protocols for Optical Star-Coupler Network using WDM," IEEE Journalon S elected Areas in Communications, Vol. 11, NO. 4, M ay 1993) に従うと、すべてのVOQの利用率がρであ る場合、1つのSMにおいて期待される空でないVOQ +ューの個数は1+(N-1)ρによって与えられる。 入すると便利である。rを任意のキューがそのスケジュ ーラによって選択される確率とする。qが当該キューが 空でないと仮定しているのに対して、rにはこの制限が ないという点で、rはqとは異なる。次式が成り立つの を見るのは困難ではない。

#### $[0084] r = \rho q = p/N$ (1)

【0085】Q。のふるまいは以下のようにモデル化す ることができる。パケット到着間時間は明らかに、パラ メータp/Nの幾何分布に従う。先頭パケットは、SM によって選択されるまで待機しなければならない。その 30 選択は、与えられたスロットにおいて確率gで起こる。 選択された後、図14のタスク105に従って、スケジ ューリングから阻止される可能性がある。与えられたス ロットにおいてポートmに対して阻止される確率がP。" である場合、先頭パケットがSMによって選択されるま での待機時間は、パラメータs=q(1-P<sub>b</sub>)の幾何 分布に従う。ことで確率はすべての出力ポートに対して 同一であるので、上付き添字mを落とすことができる。 Q<sub>m</sub>が選択された後、常に予約が将来のタイムスロット において行われ、且つパケットはキューから一種のベル\*40 【数2】

$$P_0^n = 1 + \frac{1}{N} \left[ 1 + (N+1)(1-r)^N - \frac{2[1-(1-r)^{N+1}]^{N+1}}{r} \right]$$

【0091】CORPSによれば、SMが訪れているス ロットは、このスロットが同じ出力ポートに対して前の コリジョンを解決するために使用されている場合に限 り、そのSMが予約しようとするのを阻止することがで きる。

【0092】その結果、SMがいずれかのポートを所有 する確率は、

\*トコンベヤへと送出されると仮定する。ここでパケット は、予約タイムスロットがやって来るのを待機し、やっ て来た時点でシステムから出る。

【0086】図15は、Q。キューイングシステムに用 いられるモデル全体を示す模式図である。到着パケット はまずGeo(p/N)/Geo(s)/1キューに加 わる。パケットは、このキューを出ると、追加遅延D corpsを受ける。これは、CORPSがコリジョンを解 決する特定の方法の結果生じる遅延である。これは、無 限個のサーバを有するボックスによってモデル化され る。

【0087】CORPSを通過するパケットの期待遅延 は、Geo(p/N)/Geo(s)/1に対する期待 遅延と、平均遅延〈D.o.ps〉との和によって与えられ る (M. J. Karol, M. G. Hluchyj, S. P. Morgan, "Inp ut Versus Output Queuing ona Space-Division Packet Switch", IEEE Transactions on Communications, Vo 1.COM-35, No.12, pp.1347-1356, Dec. 1987、参照)。 これは、次のように書くことができる(なお、数式中上 【0083】さらに、qと密接に関連する別の確率を導 20 付きバーで表記している平均値は、明細書本文中で〈〉 で囲んで表記しているものと同一である)。

[0088]

【数1】

$$D = \frac{p\overline{S(S-1)}}{2N\left(1 - \frac{p\overline{S}}{N}\right)} + S + \overline{D_{\text{corps}}}$$
 (2)

ただし、Sは、Geo(s)時間分布の確率変数であ る。次に、〈D.orps〉の計算について説明する。 【0089】Q。の選択された(先頭パケットがGeo (p/N)/Geo(s)/1を出た)後、いくつかの 事象が起こり得る。まず、SMmは、試行しているスロ ットを所有していないことを確認しなければならない (図14のタスク104)。スロットが、SMによっ て、出力ポートnに対して所有される確率をP。"とす る。さらに、与えられたSMが、与えられたタイムスロ ットにおいて、出力ポートnに対して阻止される確率を P。"とする。これから、次式を導くことができる。 [0090]

$$)^{N} - \frac{2[1 - (1 - r)^{N+1}]}{r}$$
 (3)

 $P_0 = 1 - (1 - P_0^*)$ (5) となる。

【0093】図14のタスク104によって生じる期待 遅延〈D。〉は次式によって与えられる。

[0094]

【数3】

50

$$\overline{D_0} = \sum_{k=1}^{N} Nk P_0^k (1 - P_0) = N \left[ \frac{P_0 - P_0^{N+2}}{1 - P_0} - (N+1) P_0^{N+1} \right]$$
(6)

【0095】SMmが最初に訪れたスロットが空いてい る場合(図14のタスク104、105、および107 のテストがすべてNO)、優先マトリクス方式が使用さ れていることにより、パケットの平均遅延〈D.o.o.〉 がNになることを見るのは容易である。〈Dcorps〉> Nで、コリジョンがない場合、少なくとも1つの予約 が、将来の第2のフレームへとこぼれる。ここで、コリ 10 【0096】 ジョンによって受ける遅延 D. について調べる。特定の スロットに対してi-1個の他のSMとのコリジョンが\*

$$P\left[D_{\text{corps}} = jN|v=1\right] = \left\{egin{array}{ll} 1 & j=i\,\emph{の場合} \ 0 & その他 \end{array}
ight.$$

となる。

【0097】上記の式は単に、SMmがスロットを訪れ る最初のSMである場合、そのパケットはNスロット遅 延されるということである。コリジョンが起こらない場 合、CORPSスケジューラは将来の1フレームをスケ 20 【0098】 ジューリングするからである。次に、SMs (s zm) の任意の出力ポート(特に出力ポートn)に対するVO※

※Qキューが空でなく、かつ、sによって選択される確率 はrであることを想起すると、P[D.orgs = jN | v = i ] に対する一般式が次のようになることを見るのは 困難ではない。

(7)

\*起こる場合、そのスロットに関してSMmが有する優先

願位に依存して、遅延 D。はNから i Nまでの間で変わ

りうる。そこで、SMmがそのスロットを訪れる i 番目

のSMである場合にパケット遅延がjNである確率をP

[D.o., = j N | v = i ] とする。例えば、mがその

スロットを訪れる最初のSMである場合、

【数5】

【数4】

$$P[D_{\text{corps}} = jN|v=i] = \begin{cases} 0 & j > i \text{ の場合} \\ \binom{i-1}{j-1}r^{j-1}(1-r)^{i-j} & その他 \end{cases}$$
(8)

【0099】式(8)の上段は、mがスロットを訪れる i 番目のSMである場合、その遅延はたかだか i Nであ るということである。下段の二項係数は、i-1個のS Mがmの前にスロットを訪れた場合、これらのうちのj 30 延は次のようになる。 -1個のSMがmと衝突する可能性があるということで ある。(Dcorps = j Nかつv = i )の形の事象の同時 分布は、上記の表式に1/Nを乗じることによって容易 に導出することができる。なぜなら、SMmは、スロッ ト1≤i≦Nのi番目の訪問者であることが等しく確か らしいからである(図7参照)。

【0100】次に、1つのパケットの期待遅延D,は次 のように導出することができる。

[0101]

【数6】

【0102】CORPSスケジューラにより生じる全遅

[0103]

$$\frac{(20)}{\overline{D_{\text{corps}}}} = \overline{D_0} + \overline{D_c} \tag{10}$$

【0104】計算すべき最後の確率はP。である。これ は、与えられた出力ポートnに対して、与えられたスロ ットにおいて、1つのSMが阻止される確率である。次 式を示すことができる。

[0105]

$$P_b^n = 1 + \frac{1}{N} \left[ 1 + (N+1)(1-r)^N - \frac{2[1-(1-r)^{N+1}]}{r} + 2 + r - \frac{(1-r)^{N+1}}{1-r} \right]$$
(11)

. 【0106】Geo(s)に対して、(S)=1/s (S(S-1))=2(1-s)/sであること に注意すると、1つのパケットがシステムで受ける全平

均遅延は次のようになる。

[0107]

【数9】

$$D = \frac{p(1-s)}{Ns^2 \left(1 - \frac{p}{Ns}\right)} + \frac{1}{s} + N \left[ \frac{P_0 - P_0^{N+2}}{1 - P_0} - (N+1)P_0^{N+1} \right] + \frac{N(N-1)}{2}r + N$$
 (12)

ただし、 $s = q(1 - P_s)$ である。最初の3項は、ス ケジューリングが行われる前の、VOQキューにおける 遅延に対応する。第3項は、CORPSのパイプライン のに必要な追加時間に対応する。

【0108】図16に、CORPSの遅延対スループッ トの解析的結果を、CORPSスケジューラを備えた1 6×16スイッチのシミュレーションと比較したものを 示す。この図において、パイプラインおよびコリジョン 解決方式が使用されることにより、バケットがSMスケ ジューラによって選択されるまでに受ける平均キューイ ング遅延と、CORPS遅延との間に違いがある。図か ら分かるように、解析的予測は、シミュレートされたシ ステムのふるまいと良く一致する。

【0109】との図は、負荷のすべての範囲を通じて、 スケジューリング遅延がキューイング遅延よりも優勢で あることを示している。非常に髙い負荷の場合(キュー が形成され始めるとき) にのみ、キューイング遅延が重 要になる。これは、パケットがVOQキューに到着する とすぐに将来のパケットをスケジューリングすることに おいて、CORPSがうまくはたらいていることを意味 する。他方、CORPSによって生じる平均遅延は、軽 負荷の場合のおよそ1フレームから、負荷が0.85に 達するときの約5フレームまで、増大する。

【0110】完全を期するため、図17に、16×16 CORPSスイッチにおける全遅延の相補分布を示す。 曲線は、シミュレーションによって得られた、負荷が 0. 8および0. 85の場合のものである。まず、いず れのパケットも、システムを通過するのにN<sup>1</sup>スロット より多くはかからないことに注目される。これは、CO RPSでは多重コリジョンが起こることを許していない ことによる。実際、分布のテールは、N<sup>2</sup>/2=128 付近のあたりで終わっているように見える。しかし、シ ステムが非常に大きい負荷によって駆動される場合、バ\*40 【数10】

\*ケット遅延はN'に近づくようである。

【0111】図18は、CORPSを実現するシステム ブロック図である。VOQMモジュールは、パケットを およびコリション解決機能により、パケットが待機する 10 仮想出力キューVOQに入れる。また、このモジュール は、与えられたキューに代わって、SMモジュールに対 して要求を行う。SMモジュールは、メッセージ受渡し を制御し、CORPSスケジューラを実現する。SMモ ジュールは、VOQMと通信して、将来のスロット予約 について通知する。この通知はVOQMに保持され、与 えられたスロットにおいて、パケットが、交換されるべ きクロスバレジスタに転送されるようにする。

> 【0112】図中、SMとクロスバコントローラの間の 通信はバスを通じて行われるように示されているが、と 20 の特定の種類の通信である必要はない。

> 【0113】スケジューリングアルゴリズムどうしの公 平な比較では、平均遅延やスループットのようなパフォ ーマンス尺度のみならず、複雑さおよび実装コストも考 慮すべきである。第1の選択基準は高いスループットで ある。さらに、VOQで動作するスケジューラのみを比 較する。そこで、本発明と競合するスケジューラとし て、1-SLIP及びRRGSとの比較を行う。複数回 のイテレーションではなく1イテレーションのSLIP を選択する理由は、比較プロセスの公平性のためであ 30 る。すなわち、任意の入力ポートにおいて、スロット当 たりたかだか1回の決定をすることができると仮定す る。i-SLIP(i>1)は、実質的に、スロット当 たり複数回のスケジューリング決定を要求することにな

【0114】パフォーマンス比較において、解析的結果 およびシミュレーション結果の両方をもとにする。一様 トラフィックに対するRRGSおよびSLIPの遅延パ フォーマンスは次のように近似することができる。

[0115]

$$\overline{D_{RRGS}} = \frac{p(1-q)}{Nq^2 \left(1 - \frac{p}{Nq}\right)} + \frac{1}{q} + \frac{N}{2}$$

$$\overline{D_{SLIP}} = \frac{pN}{2(1-p)}$$
(13)

【0116】RRGSの結果については、本出願人によ る特願平11-172584号に記載されており、SL I Pの結果については、N. McKeown, "Scheduling Cell y of California at Berkeley, 1995、に記載されてい

【0117】図19に、これらのアルゴリズムの平均遅 s inan Input-Queued Switch", PhD Thesis, Universit 50 延対スループットのパフォーマンスを、CORPSと対 照して示す。との図から明らかなように、RRGS及び CORPSは、遅延が大きくなる前には、SLIPより もずっと高い負荷にたえることができる。容易に分かる ように、これらの曲線の微分は、高負荷の場合、RRG S及びCORPSのほうがかなり小さい。しかし、いず れのアルゴリズムも、中程度から軽い負荷ではオフセッ ト遅延バジェットを有する。RRGSの場合、これは、 バイプライン法が使用されていることのみによるもので ある。CORPSの場合、既に説明したように、追加遅 延はコリジョン解決によるものである。しかし、COR 10 PSは、RRGSに比べて2つの利点を有する。

(i) SMがどの出力ポートを選択するかについて選択 の自由がある。

. (ii) 厳密に公平なスケジューラである。

SLIPもまた公平なスケジューラであるが、そのコリ ジョン解決プロセスは、CORPSのものとは全く異な

【0118】前述のように、CORPSは、どの出力ポ ートにスケジューリングを試みるかについて完全な選択 VOQに代わって、スケジューリングされる出力ポート を自由に選択することができる。このことは、スケジュ ーラ設計ストラテジの重要な部分であった。従って、多 くのアルゴリズムが、CORPSとともに、VOQ選択 に使用可能である。これまで、そのようなアルゴリズム の1つ、すなわち、空でないVOQのうちのランダム選 択について説明した。他のVOQ選択ストラテジの例も 可能である。VOQ選択ストラテジは、協調的選択スト ラテジおよび非協調的選択ストラテジという2つのクラ スに分類することができる。

【0119】非協調的VOQ選択ストラテジは、VOQ 選択決定が、他の入力ポートとは独立に、入力ポート (VOQM) どとに行われるものである。CORPSの 分析に用いたランダム選択ストラテジはこのクラスに属 する。

【0120】重み付き公平キューイング (WFQ: Weig hted Fair Queuing) は、パケット交換研究文献におい て広く知られたサービスストラテジである(例えば、H. Zhang, "Service Disciplines for Guaranteed Perfor mance Service in Packet-Switching Networks", In Pr 40 oceedings of IEEE, Vol.83, no.10, pp.1374-1396,0c t. 1995、参照)。その考え方は、所定の重みに従っ て、出力リンク容量に対して競合する複数のキューのサ ービスレートを規制するというものである。 VOQ C ORPSスイッチにおいて、出力ポート帯域は、ある種 の呼受付けコントローラによって複数のVOQMに分割 することができる。その場合に、WFQを用いて、VO Qキューの最大サービスレートが、与えられた出力ポー トのVOQM帯域分を超えないように強制することがで

【0121】レート制御サービス(RCS: Rate-Contr

28

olled Service) 規律は、与えられたトラフィックフロ ーが、ネットワークエントリポイントでいくつかのバー スト性制約を満たすと仮定する(L. Georgiadis, R. Gu erin, V. Pens, "EfficientNetwork QoS Provisioning Based on per Node Traffic Shaping", Proceedingsof INFOCOM96, vol.1, pp.102-110, 1996、参照)。これら の制約は一般に、ネットワークのエッジにおけるトラフ ィックシェーパによって強制される。さらに、トラフィ ックシェーパは、中間スイッチにも配置され、トラフィ ックが、ネットワーク内の各中間交換ポイントでそれら の制約に従うようにされる。トラフィックシェーパは一 般に、リーキーバケットアルゴリズムによって実現され る。J.Turner, "New Directions in Communications, o r Which Way to the Information Age?", IEEE Communi cations Magazine, Vol.24, pp.8-15, 1986、には、そ のようなアルゴリズムの1つが記載されている。基本的 なリーキーバケットは、2つのキュー(1つはデータ用 で、1つはトークンすなわちパーミット用)を有するシ の自由を与える。すなわち、各VOQMは、与えられた 20 ステムである。キュー上のデータパケットは、サービス を受けるためにはパーミットを必要とする。制限された 個数のパーミットのみがパーミットキューに格納され る。パーミットは、一定レートで生成される。との種の トラフィックシェーパは、VOQのうちのいずれがサー ビスを受けるかを規制するために使用可能である。適格 なVOQのうちからは、キュー選択に任意のアルゴリズ ムを用いることが可能である。

> 【0122】上記の2つのサービス規律は、パケットネ ットワークにおけるサービス品質(QoS)のサポート 30 に使用可能であり、それ自体、活発な研究分野である。 このようなQoSサポートストラテジは、非協調的なタ イプのものになることが多い。それは、他のトラフィッ クストリームとは無関係に、VOQの予測されるサービ ス挙動を保証することになるからである。このクラスに 属するアルゴリズムは、ビデオや音声ストリームのよう な、厳しいQoSアプリケーションをサポートするスイ ッチで使用可能である。

> 【0123】協調的VOQ選択ストラテジは、VOQ選 択がスイッチ内のVOQのセット全体の状態に依存する ような選択ストラテジである。このストラテジは一般 に、各フローのサービスに集中するよりも、最大スルー プットのようなスイッチ全体のふるまいを良くすること を目標とする。従って、このようなストラテジをスイッ チで使用するのは、QoS要求条件に対する約束なし に、データトラフィックをサポートする場合である。 【0124】協調的ストラテジの場合、他のVOQの状 態のような追加情報をCORPSスケジューラに提供す る必要がある。キューの状態に関する情報は常に「古 い」ため、サービスストラテジは、古い情報に関してロ 50 バストでなければならない。

【0125】最大マッチング問題とは、与えられたグラ フの辺のうちから、グラフの頂点の対をつなぐ辺で、対 の総数を最大にするような辺のサブセットを求める問題 である (Cormen, Leiserson and Rivest, "Introductio n to Algorithms", McGraw-Hill, 1990、参照)。しか し、どの頂点も、つなぐ選択された辺を複数本有すると とはできない。あらゆるスロットで交換されるパケット の個数を最大にする場合、最大2部マッチング (MB M: Maximum Bipartite Matching) 問題を解く必要があ る (R. E. Tarjan, "Data Structures and Network Alg 10 orithms", Society for Industrial and Applied Mathe matics, Pennsylvania, Nov. 1983、参照)。適当な計 算量でMBMを解くアルゴリズムが利用可能である(). E. Hopcroft, R. M. Karp, "An n<sup>5/2</sup> Algorithm for M aximum Matching in Bipartite Graphs", Society for Industrial and Applied Mathematics J. Comput., 2 (1973), pp.225-231、参照)。本発明では、VOQが空 きであるか否かの状態情報は、通信チェインを通じて送 られて、VOQMに渡される。ここで、MBMアルゴリ するかを決定する。興味深い点であるが、CORPSに よれば、MBMアルゴリズムによって選択されないキュ ーも、将来の予約を試みることが可能である。

29

【0126】最大重み2部マッチング(MWBM: Maxi mum Weight Bipartite Matching) 問題は、上記のMB M問題と類似している。主な相違点は、前者では、重み がグラフの辺に関連づけられ、目的は、マッチングの辺 の重みの総和を最大にする辺のセットを求めることであ ることである。他の研究者は、MWBMアルゴリズムを 用いると、非一様トラフィックのもとでは、スループッ トに関してMBMストラテジよりパフォーマンスが優れ ていることを示している(N. McKeown, V. Anantharam, J. Walrand, "Achieving 100% Throughput in an Inpu t-Queued Switch", Proceedings of Infocom96, San Fr ancisco, March 1996、参照)。考え方は、非一様トラ フィックの場合を扱うために、VOQキューサイズを重 みとして用いることである。

【0127】また、上記文献によれば、入力トラフィッ クが受付け可能である限り、MWBMアルゴリズムは安 定である、すなわち、VOQキューは爆発しない。あら ゆる出力ポートに対して、1個の出力ポートへの入力ト ラフィックレートの総和がその容量を超えない場合に、 トラフィックが受付け可能であるという。この興味深い 結果は、MWBNの安定性は、古い情報の存在下でも、 すなわち、重みがいくつかの過去のタイムスロットのキ ューレベルに基づいていても、維持されるということで ある。この場合も、VOQのキューレベル情報はすべて のVOQMに渡され、出力ポートに対する要求がSMへ と発行される前に、MWBMアルゴリズムが各モジュー ルで実行されるようにすることができる。

[0128]

【発明の効果】以上詳細に説明したように、本発明によ れば、まず、時間軸をフレーム化して優先マトリクスを 用いた予約を行うことにより、タイムスロット巡回順序 を規則的なものとし、実装及び制御を容易にするという 効果がある。また、RRGSとは異なり、スケジューリ ングの規則をSM個数の偶奇によって変える必要がな く、この点でも実装及び制御が簡単であるといえる。 【0129】さらに、本発明による繰越しラウンドロビ

ンパイプラインスケジューラ (CORPS) によれば、 クロスバ高速スイッチファブリックの入線間での公平な スケジューリングが可能となる。CORPSは、将来の スロットのパケットをスケジューリングすることによ り、ラインごとスロットごとに1つのスケジューリング 決定を行う。スケジューリングされるキューの選択は任 意であるため、トラフィックのサービス品質をサポート することに適している。CORPSは、出力ポート間の 競合を公平に解決する。

【0130】さらに他の効果および変形を考えることは ズムは、次フレームのスロットにどのキューがサービス 20 当業者には容易であって、本発明は、ここで説明した具 体例に限定されない。特許請求の範囲に記載した本発明 の構成の技術思想あるいは技術的範囲から離れることな く、さまざまな変形例を考えることが可能である。

【図面の簡単な説明】

【図1】集中VOQスケジューラを示す概略的ブロック 図である。

【図2】(A)は並列方式の、(B)はラウンドロビン 方式のアーキテクチャをそれぞれ示す分散スケジューラ アーキテクチャの模式図である。

【図3】入力バッファ型スイッチアーキテクチャの説明 図である。

【図4】入力ポート分散スケジューラの構成を例示する 概略的ブロック図である。

【図5】4×4クロスバースイッチを用いた場合のRR GSによるパイプラインスケジューリング決定の一例を 示すタイムチャートである。

【図6】図5を個々のSMのタイムスロット巡回順序に 着目して表現したタイムチャートである。

【図7】本発明によるスケジューラの一実施形態におけ 40 るコリジョンを解決するのに用いられる優先マトリクス の一例(ポート数N=4)を示す説明図である。

【図8】本発明によるスケジューラの一実施形態におけ るパイプラインスケジューリング決定の一例 (ポート数 N = 4 ) を示す説明図である。

【図9】本発明によるスケジューラの一実施形態におけ るコリジョンを解決するのに用いられる優先マトリクス の一例(ポート数N=5)を示す説明図である。

【図10】本発明によるスケジューラの一実施形態にお けるパイプラインスケジューリング決定の一例(ポート 50 数N=5)を示す説明図である。

31 【図11】本発明によるスケジューラの一実施形態におけるSM間の繰越し動作を示す説明図である。

【図12】本実施形態におけるSメッセージのフォーマット図である。

【図13】本実施形態におけるスケジューラモジュールのデータ構造体のフォーマット図である。

【図14】本実施形態におけるCORPSスケジューリングアルゴリズムを示すフローチャートである。

【図15】CORPS VOQキューイングモデルを示\*


\* す模式図である。

【図16】システム負荷の関数としてパケット遅延を表すグラフである。


【図17】CORPSスケジューラを備えた16×16 スイッチの相補的遅延分散を示すグラフである。

【図18】CORPSコントローラの一例を示すブロック図である。

【図19】さまざまな競合スケジューラの、システム負荷に対する期待遅延を示すグラフである。









【図6】

タイムスロット スケジュー リングモジュール	T1	Т2	Т3	T4	T5	TB	17	TB	TB	T10	T11
SM1	Т6	<b>T4</b>	17	T5	T10	T8	TII	Т9	T14	T12	T15
SM2	тз	T6	<b>T4</b>	Т9	17	T10	T8	T13	T11	T14	T12
SM3	T5	ТЗ	<b>T8</b>	Т6	Т9	17	T12	T10	T13	<b>T</b> 11	T16
SM 4	Т2	77	T5	Т8	T6	TII	Т9	T12	T10	T15	T13


【図7】




【図8】





【図12】




【図15】











【図19】

